

<https://doi.org/10.31891/2307-5732-2025-353-8>

УДК 004.89

ВОВК РОМАН

Івано-Франківський національний технічний університет нафти і газу

<http://orcid.org/0000-0003-0681-4534>e-mail: roman.vovk@nung.edu.ua**ШЕКЕТА ВАСИЛЬ**

Івано-Франківський національний технічний університет нафти і газу

<https://orcid.org/0000-0002-1318-4895>e-mail: vasyl.sheketa@nung.edu.ua**ФЕДУРУК ЕДУАРД**

Івано-Франківський національний технічний університет нафти і газу

<https://orcid.org/0009-0004-9551-5193>e-mail: ed.fedoruk@gmail.com**ПОПОВИЧ ОЛЕГ**

Івано-Франківський національний технічний університет нафти і газу

<https://orcid.org/0009-0000-9946-1613>e-mail: olehpopovych20@gmail.com**ГОЛОВЧАК ВЛАДИСЛАВ**

Івано-Франківський національний технічний університет нафти і газу

<https://orcid.org/0009-0006-2571-5258>e-mail: vladyslav.holovchak-a12322@nung.edu.ua

РОЗРОБКА МЕТОДУ ІНТЕГРАЦІЇ МАШИННОГО НАВЧАННЯ З ВИВЕДЕННЯМ НА ОСНОВІ ПРАВИЛ

У статті представлено новий метод інтеграції машинного навчання з процедурою виведення на основі правил в інтелектуальних системах, що базуються на ймовірнісних правилах. Запропонований підхід спрямований на підвищення точності прогнозування та адаптивності системи при обробці великих обсягів даних, в яких присутні різноманітні джерела невизначеності. Методика ґрунтується на використанні гнучких нейронних мереж, здатних відновлювати повну інформацію з часткових даних, що дозволяє оптимізувати вагові дескриптори правил через відповідну багаторівневу інтеграцію. Проведено детальний аналіз існуючих алгоритмів машинного навчання, структурної оптимізації бази знань системи та можливостей інтеграції з сучасними технологіями роботи з даними. Розроблена модель забезпечує ефективне врахування ступеня невизначеності в формі коефіцієнтів впевненості та адаптацію параметрів системи в умовах волатильності даних. Отримані результати відкривають перспективи застосування даного підходу в різних галузях, де потрібна застосування методик машинного навчання.

Ключові слова: багатошарова нейронна мережа, глибоке навчання, база правил, коефіцієнти впевненості, обробка даних, інтелектуальні системи на основі правил.

VOVK ROMAN, SHEKETA VASYL, FEDORUK EDUARD, POPOVYCH OLEH, HOLOVCHAK VLAD

Ivano-Frankivsk National Technical University of Oil and Gas

DEVELOPMENT OF A METHOD FOR INTEGRATING MACHINE LEARNING WITH RULE-BASED INFERENCE

This article presents a method for integrating newest AI methods into classical rule-based intelligent systems by adding a information retrieval processing layer that replaces the traditional weights coefficients calculation routine. The proposed approach involves using a multi-layer neural network as coefficients for information retrieval method, which allows implementing associative rules in the system structure and increasing its efficiency in prediction, classification, and decision-making tasks under uncertainty and fuzziness. The methodology is based on eliminating the constraints of the classical approach to weights coefficients calculation, which relies on traditional operations of according to the degree of relevance and rule weights. The integration of associative rules allows for a more complex and adaptive calculation of weights, which contributes to increasing prediction accuracy and flexibility in decision-making in complex hybrid environments. The proposed method provides automatic gaining of system parameters, including weight coefficients, neuron, and activation functions, which allows adapting to changes in input data and increases the overall performance of the system. Unlike traditional methods that use static rules and weighting coefficients, the developed approach allows dynamically updating parameters during system operation, which increases its flexibility and resilience to changing environmental conditions. The inclusion of associative rules contributes to more accurate pattern recognition in data, which improves the quality of decision-making even in cases with incomplete or missing information. Additionally, the use of automatic information retrieval reduces dependence on hard rules and lowers the need for manual system tuning, significantly simplifying its deployment and use. The obtained results demonstrates improved prediction accuracy, reduced error, and increased efficiency in data analysis. The proposed method can be used in a wide range of applications, including big data analysis, automated control of technological processes, cybersecurity, financial modeling, risk forecasting, medical diagnostics, and the development of autonomous systems for operation in conditions of high uncertainty.

Key words: multilayer neural network, deep learning, rule base, confidence factors, data processing, rule-based intelligent systems.

Стаття надійшла до редакції / Received 10.04.2025

Прийнята до друку / Accepted 25.04.2025

Постановка задачі

Метою цього дослідження є розробка та обґрунтування методу інтеграції глибокого навчання на основі асоціативної пам'яті з процедурою виведення правил в інтелектуальній системі. Запропонований метод спрямований на покращення точності прогнозування в умовах невизначеності шляхом удосконалення механізму обчислення ваг активації правил. Досягнення цієї мети передбачає формалізацію проблеми та аналіз існуючих підходів до визначення ваг активації в інтелектуальних системах, зокрема у системах, що базуються на правилах впевненості.

У межах дослідження пропонується розробка методології інтеграції глибокого навчання, що включає використання багатошарової нейронної мережі з асоціативною пам'яттю, яка дозволяє коригувати ваги активації правил, зменшуючи вплив невизначеності. Запропонований підхід ґрунтується на створенні математичної моделі взаємодії шару глибокого навчання з процедурою виведення правил, що дає змогу уточнювати ваги на основі встановлених асоціацій.

Аналіз останніх джерел

Методи глибокого навчання (DL - Deep Learning) широко застосовуються для обробки великих масивів даних завдяки меншій потребі в попередній обробці порівняно з традиційними алгоритмами машинного навчання. Водночас висока ступінь невизначеності, характерна для великих обсягів сирих даних, ускладнює досягнення високої точності прогнозування. Останні технологічні досягнення в галузі Інтернету речей (IoT) та хмарних обчислень сприяють генерації значних обсягів сирих даних. Однак ефективне прогнозування на основі цих даних залишається складним завданням для методів машинного навчання.

Точне прогнозування на основі реальних даних залишається складним завданням для різних методів машинного навчання. У сучасних наукових і промислових галузях, завдяки розвитку технологій Інтернету речей (IoT) та хмарних обчислень, відбувається безперервна генерація великих обсягів даних. Однак ці дані неминуче містять різні види невизначеності, зокрема неповноту, невідомість, неоднозначність, неточність і двозначність, що значно ускладнює процес їх ефективного аналізу та прогнозування.

Для обробки невизначених даних широко застосовуються методи, засновані на нечіткій логіці. Вони використовуються в різних прикладних сферах, зокрема в обробці зображень, управлінні портфелем активів та керуванні технологічними процесами, де невизначеність є важливим фактором [1-4]. Системи нечіткого навчання здійснюють автоматичне налаштування функцій належності та генерують нечіткі правила на основі великих навчальних вибірок [5]. Подальша обробка даних здійснюється через механізм нечіткого виведення, що дозволяє отримувати нечіткі значення, які згодом переводяться в чіткі результати за допомогою методів дефазифікації, таких як метод центру ваги, метод середнього максимуму і метод середнього значення. Проте, незважаючи на свою ефективність у вирішенні проблем, пов'язаних із неточністю, двозначністю та неоднозначністю, системи нечіткого навчання не здатні враховувати невизначеність, зумовлену неповнотою та невідомістю [6].

Методи глибокого навчання широко застосовуються для вирішення задач прогнозування на основі аналізу великих обсягів даних. Для підвищення точності прогнозування використовуються різні алгоритми глибокого навчання, що дозволяють оптимізувати процес обробки інформації, зокрема поєднання методики «випадкового лісу» із глибоким навчанням для покращення задач класифікації. У такому підході глибоке навчання використовується для вилучення високорівневих характеристик, які потім передаються «випадковому лісу» для виконання класифікаційного аналізу [7].

Метод *Fuzzy Deep Convolutional Network* (FDCN) [8] поєднує теорію нечітких множин із глибокими згортковими нейронними мережами (*Deep Residual Network*) з метою врахування невизначеності. Архітектура FDCN складається з п'яти основних компонентів: вхідного модуля, глибокої згорткової мережі (*Deep Convolutional Network, DCN*), нечіткої мережі (*Fuzzy Network, FN*), модуля злиття та прогнозуючого модуля. Вхідні дані одночасно передаються до модулів FN та DCN, після чого їхні вихідні сигнали об'єднуються в модулі злиття й передаються на прогнозуючий рівень. Оптимізація параметрів DCN та FN здійснюється шляхом мінімізації функції втрат під час навчання моделі. Після завершення процесу навчання система здатна генерувати прогнозні значення. Основна роль DCN полягає у виявленні закономірностей у вхідних даних, тоді як FN використовується для врахування невизначеності. Проте, незважаючи на переваги FDCN, нечіткі системи мають обмеження щодо обробки невизначеності, пов'язаної з неповнотою та невідомістю, що може знижувати точність прогнозування.

В моделі ієрархічної нечіткої глибокої нейронної мережі (*Fuzzy Deep Neural Network, FDNN*) [9-10] для задач класифікації даних вхідні дані одночасно обробляються нечіткою системою та модулем глибокої нейронної мережі (DNN), після чого отримані результати інтегруються та передаються до завдання-орієнтованого рівня для остаточної класифікації. Використання нечітких множин дозволяє моделі враховувати невизначеність, тоді як механізми глибокого навчання сприяють зменшенню рівня шуму у вхідних даних (*data noise*). Оцінка FDNN імплементована на задачах класифікації тканин мозку за зображеннями магнітно-резонансної томографії (МРТ) та прогнозування фондових індексів, де метод продемонстрував конкурентоспроможні результати. Водночас, одним із ключових обмежень FDNN є неможливість врахування невизначеності, що виникає внаслідок неповноти та невідомості даних. Наявність шуму у вхідних даних може призводити до їхньої неповноти або невідомості, що

негативно впливає на точність прогнозування. Оскільки нечіткі системи можуть моделювати невизначеність, зумовлену неточністю, двозначністю та неоднозначністю, але не здатні ефективно працювати з неповними або невідомими даними, точність результатууючої класифікації залишається обмеженою.

Підсумовуючи виконаний аналіз можна зробити висновок, що нечіткі системи здебільшого використовуються як окремі модулі під час інтеграції з глибоким навчанням для обробки невизначеності. Вони дозволяють моделювати невизначеність, що виникає через неточність, двозначність та неоднозначність. Однак у випадках, коли невизначеність пов'язана з неповнотою або невідомістю даних, точність прогнозування таких інтегрованих підходів залишається обмеженою.

Різні алгоритми навчання, зокрема генетичний алгоритм (GA) [11], диференціальна еволюція (DE) [12] та оптимізація рою часток (PSO) [13], активно застосовувалися для підтримки навчання в інтелектуальних системах. Вони функціонували як окремі модулі в межах інтелектуальної системи на основі правил впевненості (ІСПВ), забезпечуючи оптимізацію параметрів моделі. Поширеними є алгоритм навчання для ІСПВ, спрямовані на знаходження оптимальних значень параметрів, таких як ваги атрибутів, ваги правил і ступені впевненості, з метою підвищення точності прогнозування. Тому теоретично, можна імплементувати методи спільної оптимізації для ІСПВ, що враховують як структурні аспекти, так і параметри навчання. Гіпотетичний підхід спільної оптимізації параметрів і структури ІСПВ, може застосовувати критерій інформації як цільову функцію. Такий метод базуватиметься на використанні евристичного алгоритму для оптимізації структури та алгоритму диференціальної еволюції для налаштування параметрів. В кінцевому підсумку можна отримати вдосконалений метод спільної оптимізації на основі адаптивної диференціальної еволюції для правил впевненості з метою потенційного підвищення точності результатууючого прогнозування.

Важливим підходом є інтеграція умовного узагальненого мінімального розсіювання (CGMV - *Conditional Generalized Minimum Variance*) [14] із ІСПВ для оцінки безпеки складних технічних систем. У цьому підході CGMV використовується для відбору характеристик, тоді як ІСПВ застосовується для оцінки рівня безпеки. Обидва методи функціонують відповідно незалежно один від одного, без змін у процедурі виведення ІСПВ, що запобігає зниженню точності прогнозування в умовах обробки великих обсягів даних.

В роботі [15] представлено інтеграцію глибокого навчання з ІСПВ для прогнозування рівня забруднення повітря на основі зовнішніх зображень. У межах цієї методики згорткові нейронні мережі (CNN) використовувалися для прогнозування концентрації забруднення, а отримані результати разом із даними давачів надходили в ІСПВ для оцінки загального рівня забруднення повітря. У цьому підході CNN та ІСПВ працювали як окремі модулі, без внесення змін у процедуру виведення ІСПВ, щоб могло б обмежувати можливості системи щодо інтеграції асоціативної пам'яті та ускладнювати обробку великих обсягів даних про потенційні забруднення.

Таким чином, проведений огляд показує, що перспективним є інтеграція нечітких систем з методами глибокого навчання для моделювання невизначеності в умовах роботи з великими обсягами даних. Водночас існуючі інтеграції нечітких та глибоких методів навчання демонструють певні обмеження, зокрема неможливість урахування всіх видів невизначеності через структурні обмеження саме в класі нечітких систем. Для підвищення точності прогнозування ІСПВ використовуються вище згадані алгоритми оптимізації які інтегрувалися з ІСПВ як окремі модулі, спрямовані на підвищення ефективності її функціонування.

Однак наразі відсутні дослідження, що розглядають можливість інтеграції асоціативної пам'яті безпосередньо в процедуру виведення ІСПВ для підвищення точності прогнозування в умовах великих обсягів даних. З огляду на це, дана робота зосереджується на розробці методики інтеграції глибокого навчання на основі асоціативної пам'яті з процедурою виведення ІСПВ для покращення її прогнозних характеристик.

Виклад основного матеріалу

Інтелектуальні системи на основі правил впевненості (ІСПВ) є одним із підходів до опрацювання невизначених даних. Проте їхня обмежена здатність до інтеграції асоціативної пам'яті у процеси виведення призводить до низької точності прогнозування у випадках роботи з великими масивами даних. У зв'язку з цим у даному дослідженні запропоновано підхід, що інтегрує методи глибокого навчання на основі асоціативної пам'яті у процеси виведення ІСПВ, що сприяє виявленню точніших закономірностей у даних та підвищенню точності прогнозування в умовах невизначеності. Крім того, запропонований метод порівнювався з іншими моделями глибокого навчання, зокрема Long Short-Term Memory (LSTM) та Deep Neural Network (DNN).

ІСПВ є розширенням традиційних систем нечіткого навчання, що забезпечує покращене представлення невизначених знань шляхом інтеграції структури правил впевненості. Відомо, що типова інтелектуальна система складається з двох основних компонентів: бази знань і механізму логічного виведення, а сама база знань представляється у вигляді правил типу "Якщо-Тоді". Однак такий підхід не враховує випадки, коли рівень впевненості в настанні події є меншим за 100%. Для вирішення цієї проблеми використовується нова схема представлення знань шляхом інтеграції розподіленої оцінки, що базується на структурі впевненості. Наприклад, у випадку прогнозування

прихоплення бурильної колони під час буріння нафтових і газових свердловин правило матиме наступний вигляд:

"ЯКЩО $A1$ = "глинисті" (впевненість 0.7), $A2$ = "велике" (впевненість 0.8), $A3$ = "негативна" (впевненість 0.9), $A4$ = "значні" (впевненість 1.0)

ТОДІ: $C1$ = "Низький ризик прихоплення" (впевненість 0.1), $C2$ = "Середній ризик прихоплення" (впевненість 0.3), $C3$ = "Високий ризик прихоплення" (впевненість 0.9)"

де $A1$ – тип порід, $A2$ – відхилення свердловини від вертикалі, $A3$ – різниця між пластовим тиском і тиском бурового розчину і $A4$ – наявність осипів або обвалів.

Завдяки цій удосконаленій схемі представлення знань знайшли застосування в різних галузях, таких як прогнозування природних катастроф, медична діагностика, фінансове прогнозування та прогнозування під час буріння нафтових і газових свердловин, де проблема невизначеності відіграє ключову роль у процесі ухвалення рішень.

Існують два основні типи ІСПВ: кон'юнктивна та диз'юнктивна. У кон'юнктивній ІСПВ атрибути антецедента правила поєднуються за допомогою логічного оператора "І", що призводить до значного зростання обчислювальної складності через комбінаторний вибух і, як наслідок, збільшення кількості правил у базі знань [14], [15]. Натомість диз'юнктивна ІСПВ використовує логічний оператор "АБО" для об'єднання антецедентних умов, що зменшує обчислювальну складність і знижує кількість правил у системі.

Останнім часом глибоке навчання зарекомендувало себе як ефективний підхід для вирішення задач розпізнавання шаблонів та регресійного аналізу, що зумовлено його здатністю безпосередньо обробляти сирі дані. Проте, глибокі нейронні мережі мають обмежені можливості щодо врахування невизначеності, оскільки їхня структура не забезпечує механізмів роботи з такими аспектами, як неповнота, невідомість, двозначність, неоднозначність і неточність. У той час як ІСПВ ефективно обробляють різні типи невизначеності в єдиній інтегрованій моделі, вони не здатні використовувати асоціативну пам'ять у процесі виведення. Основна причина цього обмеження полягає в тому, що механізм виведення ІСПВ базується на арифметичних операціях множення, додавання та ділення, які не забезпечують збереження та відновлення інформації. Це унеможливило виявлення повних шаблонів на основі неповних або часткових даних.

Наприклад, під час обчислення ваги активації правила використання ступенів відповідності у рамках ІСПВ здійснюється за допомогою операцій множення та ділення. Однак такі обчислення не дозволяють отримати точні значення активації кожного правила, що, своєю чергою, впливає на механізм агрегування правил, який є критичним етапом прогнозування. У зв'язку з цим у даному дослідженні для визначення ваги активації правил із урахуванням ступенів відповідності використовується метод *Deep Neural Network (DNN)*, що є частиною підходу глибокого навчання. Використання DNN обґрунтоване тим, що цей метод базується на штучних нейронних мережах (*Artificial Neural Networks, ANN*), які є системами асоціативної пам'яті. ANN здатні відновлювати повну інформацію на основі її часткових фрагментів, а також встановлювати кореляції між вхідними даними та збереженими знаннями.

Таким чином, запропонований підхід інтегрує механізм асоціативної пам'яті для відновлення повного значення ваги активації правил із використанням ступенів відповідності. Це значно підвищує ефективність процесу виведення в ІСПВ, особливо при обробці великих обсягів даних, та забезпечує більш точні результати прогнозування. В остаточному підсумку така інтеграція сприяє покращенню загальної точності ІСПВ.

Окрім того, досягнення високої точності прогнозування вимагає оптимізації ключових параметрів навчання ІСПВ, включаючи ваги правил, ваги атрибутів та ступені впевненості. Ця оптимізація виконується за допомогою різних алгоритмів навчання. Оскільки інтеграція глибокого навчання на основі асоціативної пам'яті в ІСПВ додає нові параметри, такі як ваги нейронів і зміщення, їх також необхідно оптимізувати. Це вимагає вдосконалення механізму навчання ІСПВ. Оптимізація параметрів асоціативної пам'яті відіграє ключову роль у підвищенні точності прогнозування системи.

Правило впевненості має дві частини: одна — це антецедент або преміса, яка складається з антецедентних атрибутів; інша — це консеквент або висновок, який містить консеквентний атрибут. Антецедентні атрибути використовують референтні значення, а ступені впевненості пов'язані з консеквентним атрибутом правила впевненості. Кожне правило впевненості має призначену вагу правила для позначення його важливості.

Після створення бази правил процедура виведення використовується для генерування виходу. Процедура виведення складається з різних етапів, які показані на рис. 1. Це трансформація входу, активація правил, обчислення ваги, оновлення ступеня впевненості та агрегація правил за допомогою підходу доказового міркування. Вхідні дані розподіляються по референтних значеннях антецедентних атрибутів, що називається ступенем відповідності, досягнутим через процес трансформації входу. Потім правила впевненості називаються пакетом антецедентів, а ваги активації правил обчислюються за допомогою ступенів відповідності.




Рис. 1. Робочий процес побудови рішення в ІСПВ

У диз'юнктивному припущенні всі рівні відповідності підсумовуються для врахування поведінки оператора АБО у правилах впевненості. Важливо також зазначити, що обчислення повного значення ваги активації правила за допомогою операторів множення, сумування та ділення є складним завданням. Це зумовлено обмеженнями традиційних обчислювальних підходів, тоді як в асоціативній пам'яті така обробка є можливою завдяки її здатності до ефективного збереження та обробки патернів.

У випадку ігнорування будь-яких з антецедентних атрибутів необхідно скоригувати ступінь впевненості, пов'язаний із кожним правилом. Це оновлення здійснюється згідно з рівнянням (1).

$$CF_{jk} = \overline{CF_{jk}} = \frac{\bigcup_{t=1}^{T_k} fconstr(\psi(t,k) \bigcup_{i=1}^t fconstr(rc[r]_{ti}))}{\bigcup_{t=1}^{T_k} fconstr(\psi(t,k))}, \quad (1)$$

де $fconstr$ - функція співставлення, $\psi(t,k) \in [0..1]$, якщо t атрибут використовується у визначенні правила $RL_k (k = 1, \dots, T_k)$.

Тут $\overline{CF_{jk}}$ представляє початковий ступінь впевненості, тоді як оновлений ступінь впевненості CF_{jk} k -го правила, $rc[r]_{ti}$ представляє ступінь, до якого вхідне значення належить атрибуту. Потім агрегація правил виконується за допомогою рекурсивного алгоритму міркування.

Нечіткий вихід процедури агрегації правил перетворюється в чітке значення за допомогою значень корисності консеквентного атрибута, яке вважається остаточним очікуваним результатом $exp c_i$.

У підсумку, вхідні дані $item_1, item_2, \dots, item_n$ зіставляються з відповідними ступенями відповідності референтних значень $RC_1, RC_2, \dots, RC_{T_k}$ антецедентних атрибутів, як проілюстровано на рис. 1. На початковому етапі виконується трансформація вхідних даних (нормалізація, вилучення ознак, перетворення типів, тощо), у результаті якої визначаються ступені відповідності. Далі, на основі отриманих ступенів відповідності обчислюються ваги активації правил, які показують, наскільки сильно кожне правило впливає на кінцевий результат.

Під час етапу оновлення ступеня впевненості модифікуються їх ступені, пов'язані з правилами. Метод доказового міркування використовується для комбінування інформації з різних правил та отримання остаточного висновку. На наступному етапі, в процесі агрегації правил, використовується рекурсивний алгоритм міркування для формування нечіткого вихідного значення. Це значення потім перетворюється в чітке значення за допомогою функції корисності.

Невизначеність, що виникає внаслідок неоднозначності, неточності, двозначності, неповноти та невідомості, враховується за допомогою схеми впевненості, етапу оновлення ступеня впевненості та процедури виведення на основі доказового міркування. Завдяки реалізації зазначених етапів ІСПВ забезпечує комплексний підхід до обробки різних видів невизначеності.

Глибоке навчання є підходом до машинного навчання, що дозволяє автоматично виявляти релевантні представлення даних для виконання задач прогнозування або класифікації. Найбільш базова архітектура глибокого навчання складається з вхідного, прихованого та вихідного шарів. Вхідні дані подаються на вхідний шар і передаються через один або декілька прихованих шарів, що є основною характеристикою "глибини" мережі. Кожен шар містить множину нейронів, кожен із яких використовує функцію активації для формування нелінійних представлень даних, що сприяє виявленню важливих характеристик.

Математично нейрон описується наступними рівняннями:

$$\exp_c_i^l = WC_i^l * item^l + bn_i^l, \quad (2)$$

де WC — ваговий коефіцієнт, $item$ — вхідний сигнал, а bn_i^l — зміщення для i -го нейрона в l -му шарі.

Вихідне значення нейрона визначається за допомогою функції активації:

$$y_val = F_act(\exp_c_i^l), \quad (3)$$

де F_act — функція активації, що забезпечує нелінійність моделі та дозволяє ефективніше навчати глибокі архітектури.

Серед поширених методів глибокого навчання виділяють глибокі нейронні мережі (*DNN* – *Deep Neural Networks*), згорткові нейронні мережі (*CNN* - *Convolutional Neural Networks*), довготривалу короткочасну пам'ять (*LSTM* - *Long Short-Term Memory*) та рекурентні нейронні мережі (*RNN* - *Recurrent Neural Networks*). Для навчання цих моделей застосовуються різні методи оптимізації. Зокрема, для оновлення параметрів нейронної мережі використовується метод градієнтного спуску, однак він має обмеження щодо ефективності у випадку глибоких мереж через значні обчислювальні витрати. У зв'язку з цим для навчання моделей глибокого навчання з використанням алгоритму зворотного поширення помилки зазвичай застосовується стохастичний градієнтний спуск (*SGD*), що дозволяє підвищити ефективність процесу навчання.

Тепер розглянемо інтеграцію методів глибокого навчання з ІСПВ. Архітектура такої системи включає базову систему інтелектуальну систему на основі правил та відповідну процедуру виведення. Робочий процес методу виведення правил в інтелектуальній системі із залученням глибокого навчання зображено на рис. 2.




Рис.2. Процес виведення правил в інтелектуальній системі з використанням глибокого навчання

Процедура виведення правил з використанням глибокого навчання складається з чотирьох основних етапів:

1. Трансформація вхідних даних;
2. Обробка глибоким навчанням;
3. Оновлення ступеня впевненості;
4. Агрегація правил.

Детальний опис кожного з етапів наведено нижче.

1. Трансформація вхідних даних

На початковому етапі вхідні дані перетворюються на ступені відповідності референтним значенням антецедентних атрибутів. Ця трансформація позначена на рис. 2 як "А" та є критичним кроком для подальшого аналізу.

2. Обробка глибоким навчанням

Другий етап, позначений як "Б" на рис. 2, передбачає використання методів глибокого навчання, таких як глибокі нейронні мережі (*DNN*), довготривала короткочасна пам'ять (*LSTM*) та згорткові нейронні мережі (*CNN*). У рамках цього дослідження застосовано *DNN*.

На даному етапі формується багатошарова нейронна мережа, яка складається з вхідного шару, кількох прихованих шарів та вихідного шару. Вхідний шар отримує ступені відповідності, отримані під час трансформації вхідних даних. Кількість нейронів у цьому шарі визначається загальною кількістю

референтних значень. Прихований шар може містити N1 шарів, кожен з яких включає N2 нейронів, при цьому всі нейрони є повністю зв'язаними.

Вихідний шар містить стільки нейронів, скільки є правил впевненості у базі знань. Нейрони вихідного шару використовують рівняння (4) та (6) для обчислення ваг активації правил впевненості. Ці ваги визначають рівень активації відповідних правил. Початкові ваги нейронів ініціалізуються випадковими значеннями, тоді як зміщення встановлюються рівними нулю.

$$\exp_c_i = (w_i * rc_i) + bn_i, \quad (4)$$

де w_i – це вага, rc_i – ступінь відповідності, а bn_i – зміщення.

$$w_act_i = \max(0, \exp_c_i), \quad (5)$$

де w_act_i – вага активації.

$$w_act_i = \frac{\exp(\exp_c_i)}{\bigcup \text{fconstr}(\exp(\exp_c_i))}, \quad (6)$$

де w_act_i – вага активації.

Найпростіша асоціативна пам'ять може бути представлена рівнянням (12), де in_templ – це вхідний шаблон, out_templ – вихідний шаблон, а Mem_Matrix – матриця пам'яті.

$$out_templ = ff(Mem_Matrix, in_templ), \quad (7)$$

Рівняння (4) моделює механізм асоціативної пам'яті, де rc_i є вхідним значенням, $\exp_c_i$ – вихідним, а w_i – компонентом пам'яті. Таким чином, можна зробити висновок, що ІСПВ на основі глибокого навчання використовує функцію асоціативної пам'яті для обчислення ваги активації, що забезпечує більш точне виявлення закономірностей у даних порівняно з традиційними методами обчислення ваги активації.

Зокрема, в традиційному підході, розраховується вага активації шляхом виконання операцій множення та ділення між ступенем відповідності $rc[r]_i$ та вагою правила WR . Однак тут не містяться змінні для збереження проміжних станів, подібно до пам'яті Mem_Matrix , що використовується в рівнянні (7).

Запропонований підхід із застосуванням асоціативної пам'яті дозволяє не лише зберігати шаблони, але й визначати відповідні ваги активації, що, у свою чергу, сприяє більш точному прогнозуванню вихідних значень.

У глибоких нейронних мережах (DNN) пам'ять виконує функцію асоціативного відновлення, що дозволяє реконструювати повну інформацію на основі її часткового представлення. Рівняння (6) визначає процес отримання повної інформації через механізм асоціативної пам'яті, що узгоджується з рівнянням (4). Таким чином, ІСПВ, інтегруючи DNN, отримує здатність до асоціативного запам'ятовування та відновлення даних, що забезпечує точніше обчислення ваги активації правил.

Інтеграція DNN у процес виведення ІСПВ значно підвищує його ефективність, оскільки механізм асоціативної пам'яті дозволяє зменшити рівень невизначеності при обчисленні ваги активації правил.

3. Оновлення ступеня впевненості

Третій етап — це оновлення ступеня впевненості, яке обчислюється за допомогою рівняння (1). Оновлення впевненості допомагає врахувати невизначеність через невідомість, яка виникає через відсутність антецедентного атрибута. Цей етап позначено як “В” на рис. 2.

4. Агрегація правил

Четвертий етап — це агрегація правил. В результаті цього етапу генерується нечітке значення, яке потім перетворюється в чітке значення, що є прогнозованим виходом. Цей етап позначено як “Г” на рис. 2. оновлення ступеня впевненості та доказове міркування враховують невизначеність через неоднозначність, неточність, двозначність, неповноту та невідомість.

Процес представлений на рисунку 2, поєднує в собі переваги глибокого навчання та інтелектуальних систем, заснованих на правилах. Шар глибокого навчання дозволяє вилучати складні ознаки з вхідних даних, а база правил та інтерфейс на основі доказового міркування забезпечують можливість інтерпретації та пояснення результатів.

Узагальнюючи, запропонований метод на основі глибокого навчання забезпечує обробку всіх видів невизначеності шляхом виконання послідовних етапів: перетворення вхідних даних, оновлення ступенів впевненості і агрегації правил. Використання глибокого навчання сприяє інтеграції асоціативної пам'яті з інтелектуальною системою, що дозволяє виявляти приховані закономірності в даних з високою точністю. Таким чином, можна дійти висновку, що поєднання глибокого навчання та ІСПВ підвищує точність прогнозування в системі завдяки ефективному розпізнаванню структурованих залежностей у даних за умов невизначеності.

Процес навчання відіграє ключову роль у визначенні оптимальних параметрів моделі ІСПВ з використанням глибокого навчання, що забезпечує її ефективне функціонування на основі навчального набору даних. Зазначені параметри можуть бути попередньо задані експертами або обрані випадковим чином. У контексті ІСПВ основними параметрами навчання є вагові коефіцієнти атрибутів WR_k , ваги

правил WA_i та ступені впевненості CF_k . Додатково, у разі використання глибокого навчання, включаються такі параметри, як ваги нейронів w_i і зміщення bn_i , відповідно до вимог методів DNN.

Антецедентні атрибути та правила впевненості впорядковуються на основі відповідних ваг атрибутів і правил, тоді як ступені впевненості консеквентного атрибута застосовуються для моделювання невизначеності вихідних даних. Таким чином, параметри навчання є невід'ємною складовою системи, і для їх визначення необхідний ефективний метод оптимізації. Навчання ІСПВ з використанням глибокого навчання на основі реальних даних дозволяє отримати оптимальні значення параметрів, що покращує якість прогнозування.



Рис.3. Процес навчання інтелектуальної системи з використанням глибокої нейронної мережі

Для оптимізації параметрів необхідно мінімізувати різницю $\Delta_{(R)}$ між спостережуваними вихідними значеннями in_val та змодельованими вихідними значеннями $\overline{in_val}$, що визначається рівнянням (8) і показано на рисунку 3:

$$\Delta_{(R)} = \frac{1}{L} \bigcup_{l=1}^L fconstr((in_val - \overline{in_val})^2), \quad (8)$$

Розглянемо основні етапи навчання системи (рис. 3):

1. Збір даних.

На першому кроці відбувається збір даних, які представляють поведінку реальної системи. Ці дані складаються з пар "вхід-вихід".

2. Ініціалізація моделі.

Моделі системи ініціалізується з початковими значеннями параметрів R , які включають в себе ваги нейронної мережі, параметри бази правил впевненості та інші налаштування моделі.

3. Прямий прохід (*Forward Pass*).

Для кожного вхідного набору даних з навчальної вибірки виконується прямий прохід через модель системи. Це означає, що вхідні дані передаються через шар глибокого навчання, потім через базу правил впевненості та інтерфейс ER для отримання змодельованого виходу.

4. Обчислення похибки (*Error Calculation*).

Змодельований вихід $\overline{in_val}$ порівнюється з спостережуваним виходом in_val реальної системи і обчислюється похибка $\Delta_{(R)}$, яка представляє різницю між $\overline{in_val}$ та in_val . Зазвичай використовується функція втрат (*loss function*), така як середньоквадратична помилка (*mean squared error*), для обчислення похибки.

5. Оптимізація параметрів (*Parameter Optimization*).

Мета навчання полягає в тому, щоб мінімізувати похибку $\Delta_{(R)}$. Для цього використовуються алгоритми оптимізації, такі як градієнтний спуск (*gradient descent*) або його варіанти. Алгоритм оптимізації коригує параметри R моделі системи на основі градієнта похибки, щоб зменшити її значення.

6. Ітерації навчання (*Training Iterations*).

Кроки 3-5 повторюються протягом кількох ітерацій або епох (*epochs*) і на кожній ітерації модель системи отримує нові дані з навчальної вибірки, обчислює похибку та коригує свої параметри. Процес навчання триває до тих пір, поки похибка не досягне прийнятного рівня або поки не буде досягнута максимальна кількість ітерацій.

7. Валідація та тестування (*Validation and Testing*).

Після завершення навчання модель валідується на окремому наборі даних, щоб оцінити її продуктивність на нових даних. Якщо модель показує задовільні результати на валідаційному наборі, вона може бути протестована на тестовому наборі даних для остаточної оцінки її продуктивності.

Навчання інтелектуальної системи також включає налаштування гіперпараметрів, таких як швидкість навчання, кількість шарів нейронної мережі та інші параметри моделі. Глибоке навчання дозволяє вилучати складні ознаки та виявляти закономірності в даних, що особливо важливо для складних систем. База правил впевненості забезпечує можливість інтерпретації та пояснення результатів, що робить модель більш прозорою та зрозумілою.

Процес оптимізації параметрів формулюється як задача мінімізації:

$$ERR = P(\theta(REF_j), WR_k, WA_k, CF_{ik}, w_i, bn_i) \quad (9)$$

де цільова функція ґрунтується на правилах рекурсивного алгоритму міркування. Крім того, для забезпечення коректності моделі необхідно виконувати такі обмеження:

- значення корисності консеквентних атрибутів та антецедентних атрибутів повинні задовольняти умову: $\theta(REF_j), j = 1, \dots, n, \theta(REF_i) < \theta(REF_j) \text{ нпуі} < j$;
- ваги правил WR_k повинні належати інтервалу: $0 \leq WR_k \leq 1, k = 1, \dots, K$;
- ваги антецедентних атрибутів WA_k також обмежені діапазоном: $0 \leq WA_k \leq 1, k = 1, \dots, K$;
- ступені впевненості консеквентного атрибута для k-го правила повинні відповідати наступним обмеженням: $0 \leq CF_{jk} \leq 1, j = 1, \dots, n, k = 1, \dots, L, \sum_{j=1}^n CF_{jk} = 1$;
- ваги нейронів w_i і зміщення нейронів bn_i повинні належати наступним діапазонам відповідно: $0 \leq w_i \leq 1, 0 \leq bn_i \leq 1$.

Для визначення оптимальних значень параметрів навчання, ваг нейронів і значень зміщення можна використати функцію *fmincon*, доступну в середовищі MATLAB, що реалізує процедуру оптимізації.

У запропонованому методі інтеграції машинного навчання в інтелектуальній системі додано шар обробки глибоким навчанням, замінивши етап обчислення ваги активації. DNN, який є багатошаровою нейронною мережею, використовується як метод глибокого навчання. Шар обробки глибоким навчанням містить асоціативну пам'ять. Етап обчислення ваги активації ІСПВ використовує операції множення, сумування та ділення за допомогою ступенів відповідності та ваг правил. Отже, цей етап не містить жодного компонента асоціативної пам'яті, що призводить до неповного обчислення ваг активації правил. Однак шар обробки глибоким навчанням дозволяє обчислювати повні значення ваг активації правил. Отже, ІСПВ з інтеграцією методу глибокого навчання на основі асоціативної пам'яті в процеси виведення правил дозволяє більш точно прогнозувати в умовах невизначеності. Крім того, під час процесу навчання такої системи включення додаткових параметрів, таких як ваги та зміщення нейронів, відіграє важливу роль у підвищенні точності прогнозування.

Висновки

У представленому дослідженні розглянуто метод інтеграції машинного навчання в інтелектуальну систему шляхом додавання шару обробки глибоким навчанням, що замінює традиційний етап обчислення ваги активації. Використання багатошарової нейронної мережі (DNN) як методу глибокого навчання дозволяє реалізувати асоціативну пам'ять у структурі інтелектуальної системи. Запропонований підхід усуває обмеження традиційного обчислення ваг активації, що ґрунтується на операціях множення, сумування та ділення відповідно до ступенів відповідності та ваг правил. Включення асоціативної пам'яті забезпечує повніше обчислення ваг активації правил, що підвищує точність прогнозування в умовах невизначеності. Крім того, під час навчання системи виконується додаткове налаштування параметрів, таких як ваги та зміщення нейронів, що сприяє підвищенню ефективності прийняття рішень. Отже, запропонований метод покращує адаптивність та точність інтелектуальних систем, що базуються на правилах впевненості.

Подальші напрями роботи будуть зосереджені на дослідженні впливу різних параметрів моделі, зокрема типів активаційних функцій та механізмів регуляризації, на точність прогнозування.

Література

1. Dumitrescu, C., Ciotirnae, P., & Vizitiu, C. (2021). Fuzzy logic for intelligent control system using soft computing applications. *Sensors*, 21(8), 2617.
2. Daradkeh, Y. I., Tvoroshenko, I., Gorokhovatskyi, V., Latiff, L. A., & Ahmad, N. (2021). Development of effective methods for structural image recognition using the principles of data granulation and apparatus of fuzzy logic. *IEEE Access*, 9, 13417-13428.
3. Luo, N., Yu, H., You, Z., Li, Y., Zhou, T., Jiao, Y., ... & Qiao, S. (2023). Fuzzy logic and neural network-based risk assessment model for import and export enterprises: A review. *Journal of Data Science and Intelligent Systems*, 1(1), 2-11.
4. Murugesan, G., Ahmed, T. I., Bhola, J., Shabaz, M., Singla, J., Rakhra, M., ... & Samori, I. A. (2022). Fuzzy logic-based systems for the diagnosis of chronic kidney disease. *BioMed Research International*, 2022, 2653665.
5. Gu, X., Han, J., Shen, Q., & Angelov, P. P. (2023). Autonomous learning for fuzzy systems: a review. *Artificial Intelligence Review*, 56(8), 7549-7595.
6. Verstraete, J., Radziszewska, W., Kaczmarek-Majer, K., & Bykuć, S. (2024). Combined defuzzification under shared constraint. *IEEE Transactions on Fuzzy Systems*, 32(5), 3049-3058.
7. Hu, J., & Szymczak, S. (2023). A review on longitudinal data analysis with random forest. *Briefings in bioinformatics*, 24(2), bbad002.
8. Chen, X., Li, D., Wang, P., & Yang, X. (2019). A deep convolutional neural network with fuzzy

rough sets for FER. *IEEE Access*, 8, 2772-2779.

9. Atanassov, K., Sotirov, S., & Pencheva, T. (2023). Intuitionistic fuzzy deep neural network. *Mathematics*, 11(3), 716.

10. Aghaeipoor, F., Sabokrou, M., & Fernández, A. (2023). Fuzzy rule-based explainer systems for deep neural networks: From local explainability to global understanding. *IEEE Transactions on Fuzzy Systems*, 31(9), 3069-3080.

11. Katoch, S., Chauhan, S. S., & Kumar, V. (2021). A review on genetic algorithm: past, present, and future. *Multimedia tools and applications*, 80, 8091-8126.

12. Das, S., & Suganthan, P. N. (2010). Differential evolution: A survey of the state-of-the-art. *IEEE transactions on evolutionary computation*, 15(1), 4-31.

13. Wang, D., Tan, D., & Liu, L. (2018). Particle swarm optimization algorithm: an overview. *Soft computing*, 22(2), 387-408.

14. Li, G., Zhou, Z., Hu, C., Chang, L., Zhou, Z., & Zhao, F. (2017). A new safety assessment model for complex system based on the conditional generalized minimum variance and the belief rule base. *Safety science*, 93, 108-120.

15. Zhang, C., Yan, J., Li, C., Rui, X., Liu, L., & Bie, R. (2016, October). On estimating air pollution from photos using convolutional neural network. In *Proceedings of the 24th ACM international conference on Multimedia* (pp. 297-301).